



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Žilina, 2026

Ing. Milan Marčan



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

Ing. Milan Marčan

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Trasovanie v adaptívnych logistických systémoch

Na získanie akademického titulu **doktor**
(„**philosophiae doctor**“, v skratke „**PhD.**“)
v študijnom odbore Strojárstvo
v študijnom programe Priemyselné inžinierstvo

Žilina 2026

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Žilinskej univerzite v Žiline, Strojníckej fakulte, Katedre priemyselného inžinierstva.

Predkladateľ: Ing. Milan Marčan
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra priemyselného inžinierstva

Školiteľ: doc. Ing. Patrik Grznár, PhD.
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra priemyselného inžinierstva

Oponenti:

1. prof. Ing. Martin Straka, PhD.
Ústav logistiky a dopravy, FBERG
Technická univerzita v Košiciach,
Park Komenského 14, 042 00 Košice
2. doc. Ing. Ján Vachálek, PhD.
Ústav automatizácie, informatizácie a merania, Sjf
Slovenská technická univerzita
Nám. slobody 17, 812 31 Bratislava
3. Ing. Andrej Štefánik, PhD.
Asseco CEIT, a.s.
Univerzitná 8661/6A
010 08 Žilina

Autoreferát bol rozoslaný dňa: 29.05.2026

Obhajoba dizertačnej práce sa koná dňa 20.08.2026 o 10:00 hod. v miestnosti BC105 na Sjf, Univerzitná 8215/1, 010 26, Žilina, pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou v študijnom odbore Strojárstvo, v študijnom programe Priemyselné inžinierstvo, vymenovanou dekanom Strojníckej fakulty, Žilinskej univerzity v Žiline.

S dizertačnou prácou je možné sa oboznámiť na referáte pre vedu a výskum dekanátu Sjf, UNIZA, Univerzitná 8215/1, 010 26 Žilina.

prof. Ing. Branislav Mičieta, PhD.
predseda komisie pre obhajobu dizertačnej práce

ÚVOD

Globálny výrobný priemysel prechádza transformáciou, ktorá zásadne mení spôsob návrhu a výroby produktov. Skracovanie životných cyklov, globálna konkurencia a extrémne požiadavky zákazníkov na personalizáciu výrobkov si vyžiadali definitívny ústup od tradičných liniek hromadnej výroby k flexibilným výrobným systémom a adaptívnym architektúram. V týchto prostrediach sa osvedčil koncept kompetenčných ostrovov, v ktorých sa samotný produkt stáva aktívnym inteligentným agentom a autonómne si volí trasu výrobnou halou podľa technologického postupu a momentálnej vyťažnosti výrobných kapacít.

Kritickým úzkym miestom týchto technologicky pokročilých tovární sa však stáva vnútropodniková logistika a riadenie toku materiálu medzi ostrovmi. Flotily AGV sú v súčasnosti riadené predovšetkým deterministickými grafovými algoritmi (napríklad A-star). Tie síce garantujú najkratšiu trasu v statickom prostredí, no pri stochastických výkyvoch dopytu a dynamických zmenách layoutu zlyhávajú. Zhlukovanie dopravy na „najkratších“ úsekoch vedie k saturácii siete, tvorbe kolón a vzniku mŕtvych bodov, čo znižuje celkovú priepustnosť systému.

Prekonanie tejto logistickej bariéry vyžaduje prechod od reaktívneho riadenia k prediktívnej autonómii. Súčasný výskum ukazuje, že riešením je integrácia digitálneho dvojčata v reálnom čase s prvkami hybridnej umelej inteligencie. Aplikáciou metód posilňovaného učenia získava logistický systém schopnosť učiť sa zo svojich predchádzajúcich rozhodnutí a proaktívne identifikovať formujúce sa úzke miesta. Vďaka tomu dokáže riadiaci systém distribuovať záťaž na alternatívne trasy ešte pred fyzickým vznikom kolízie.

Hlavným vedeckým cieľom predkladanej dizertačnej práce je navrhnúť metodiku trasovania pre logistiku adaptívnych systémov. Práca je štruktúrovaná od mapovania teoretických východísk Priemyslu 4.0, cez návrh originálneho sedemblokového architektonického prístupu spájajúceho deterministickú logiku A-star s dynamikou Q-learningu, až po simulačné overenie. Pomocou metód plánovania experimentov a analýzy rozptylu v prostredí Tecnomatix Plant Simulation má práca ambíciu exaktne preukázať, že hybridná umelá inteligencia prinesie nielen merateľné zvýšenie priepustnosti, ale vytvorí plne aplikovateľnú architektúru pre odolné továrne blízkej budúcnosti.

1 PREHĽAD PROBLEMATIKY

Súčasnú globálnu trhové prostredie sa vyznačuje neustále sa zvyšujúcimi požiadavkami na personalizáciu a kustomizáciu produktov. Tento trend, často označovaný ako hromadná kustomizácia, vedie k radikálnemu skracovaniu životného cyklu výrobkov a nutnosti vysokej flexibility výrobných systémov. Klasické linkové usporiadanie výroby, charakteristické pre hromadnú a sériovú výrobu minulých dekád, nedokáže dostatočne rýchlo a nákladovo efektívne reagovať na stochastické zmeny v dopyte. Z tohto dôvodu nastáva v rámci implementácie konceptov inteligentného priemyslu (Priemysel 4.0) nevyhnutný prechod k rekonfigurovateľným, agilným a modulárnym výrobným architektúram. (Siafara, 2018, Van, 2023, Shen, 2024)

V popredí vedeckého aj priemyselného záujmu sa čoraz častejšie ocitajú tzv. kompetenčné ostrovy, ktoré nahrádzajú rigidné výrobné linky. V systéme kompetenčných ostrovov nie je tok materiálu vopred striktné a sekvenčne daný. Samotný produkt (respektíve inteligentný agent, ktorý ho reprezentuje v kybernetickej sieti) si dynamicky volí, na ktorom ostrove, na akom konkrétnom stroji a v akom čase bude prebiehať nasledujúca technologická operácia v závislosti od momentálnej vyťaženia kapacít. Tento prechod k bunkovej výrobe však prenáša obrovský nápor na podnikovú intralogistiku, ktorá sa rýchlo stáva kritickým úzkym miestom celého produkčného hodnotového toku. Na zabezpečenie autonómneho transportu materiálu, dielov a polotovarov sa hromadne nasadzujú flotily automaticky riadených vozidiel (AGV – Automated Guided Vehicles). Ich bezkolízna koordinácia a riadenie v silne dynamickom prostredí je v súčasnosti jedným z najpálčivejších problémov priemyselného inžinierstva. (Grznár, 2020, Mozol, 2020, Mozolová, 2021)

Z hľadiska komplexného literárneho a praktického prieskumu, ktorý bol súčasťou spracovania dizertačnej práce, možno identifikovať niekoľko dominantných prístupov k riešeniu problému hľadania optimálnej trasy a operatívneho trasovania pre logistické vozidlá. Veľká časť súčasných komerčných Fleet Management systémov sa naďalej spolieha predovšetkým na tradičné deterministické algoritmy trasovania. Medzi celosvetovo najčastejšie využívané patria Dijkstrov algoritmus a najmä jeho heuristická nadstavba v podobe algoritmu A-star. (Xiao, 2024, Guo, 2023)

Tieto grafové prístupy poskytujú z matematického hľadiska exaktné garancie nájdenia najkratšej možnej cesty, pričom využívajú euklidovskú alebo manhattanskú heuristiku na zrýchlenie a usmernenie výpočtu smerom k cieľovému uzlu. Závažným problémom a výrazným obmedzením deterministických prístupov je však ich absolútne statická povaha. Vo vysoko saturovanom prostredí s vysokou prevádzkovou hustotou – čo je typickým znakom moderných hál s desiatkami nasadených AGV – deterministický algoritmus odošle viaceré vozidlá na rovnakú, zdanlivo najrýchlejšiu a najkratšiu trasu. Tento prístup nevyhnutne vedie k masívnemu zhlukovaniu dopravy na hlavných ťahoch, tvorbe dlhých kolón, zbytočnému nárastu čakacích dôb na vnútrozávodných križovatkách a v kritických prípadoch k vzniku fatálnych uviaznutí. Vznikajú tzv. mŕtve body, z ktorých sa systém nedokáže autonómne dostať bez toho, aby bol nevyhnutný manuálny a externý zásah obsluhy, čo devaluje samotnú podstatu automatizácie. (Berndt, 2022, Dittler, 2023)

V snahe prekonať limity reaktívneho a deterministického plánovania sa vedecká komunita v posledných rokoch masívne zameriava na aplikáciu pokročilých prvkov umelej inteligencie (AI), predovšetkým v oblasti posilňovaného učenia. Ako obzvlášť perspektívny sa javí koncept Q-learningu. Táto metóda umožňuje vytvorenie inteligentných agentov, ktorí sa prostredníctvom neustálej

stochastickej interakcie s prostredím učia prijímať optimálne rozhodnutia na základe definovaného systému odmien a trestov. V kontexte trasovania logistických flotíl umožňuje Q-learning zohľadňovať nielen statickú vzdialenosť, ale predovšetkým aktuálnu a predikovanú vyťaženosť jednotlivých úsekov logistickej siete. (Pimrntel, 2018, Quadras, 2022)

Podrobný literárny prieskum a analýza prípadových štúdií však odhalili, že hoci aplikácia čistého Q-learningu prináša zlepšenie v celkovej adaptabilite, naráža na zásadný technický problém známy ako preklatie dimenzionality. S rastúcou veľkosťou logistickej mapy a počtom pohybujúcich sa objektov exponenciálne rastie matica stavov, čo vedie k extrémne dlhým časom potrebným na konvergenciu a tréning učiaceho sa modelu. Navyše, modely strojového učenia, nasadené samostatne, majú často pre prevádzkovateľov nepríjemný charakter „čiernej skrinky“, čo významne znižuje dôveru manažmentu a brzdí ich reálne nasadenie v bezpečnostne kritických priemyselných prevádzkach. (ElMaraghy, 2022)

Dôležitým prvkom úspešnej aplikácie adaptívneho riadenia je využitie konceptu digitálneho dvojčata. Toto spojenie virtuálnej a fyzickej reality umožňuje zrkadliť logistické procesy do simulačných prostredí, ako je napríklad Tecnomatix Plant Simulation. Avšak súčasný výskum a prax ukazujú, že vo väčšine analyzovaných podnikov je digitálne dvojča limitované a využívané skôr v off-line režime na úvodnú makroskopickú optimalizáciu layoutu a statické rozvrhovanie. (Wiedemann, 2024)

Prechod na skutočne inteligentné riadenie vyžaduje uzatvorenie kybernetickej slučky. Fyzická vrstva podniku musí byť zosieťovaná prostredníctvom moderných protokolov priemyselného internetu vecí (IIoT). V súčasnom stave techniky začínajú dominovať protokoly štandardu OPC-UA, zabezpečujúce bezpečný prenos plošných stavových parametrov strojov, a MQTT protokol, ktorý svojou asynchrónnou a odľahčenou architektúrou umožňuje bleskovú obojsmernú komunikáciu s rýchlo sa pohybujúcimi flotilami AGV. Napriek dostupnosti týchto technológií existuje na trhu a v akademickej sfére kritický nedostatok ucelených systémových architektúr, ktoré by dovoľovali digitálnemu dvojčatu fungovať vo vysokej frekvencii v reálnom čase, anticipovať preťaženie siete a bleskovo re-trasovať vozidlá pred vznikom logistického kolapsu. (Zhou, 2024, Teerasoponpong, 2021)

Analýza súčasného stavu potvrdila, že moderné produkčné systémy prechádzajú fundamentálnou transformáciou. Zatiaľ čo teoretické koncepty Priemyslu 4.0 a komplexných adaptívnych systémov sú v literatúre veľmi dobre ukotvené, ich prienik do operatívneho riadenia vnútro podnikovej logistiky v prostredí kompetenčných ostrovov vykazuje značné nedostatky.

2 STANOVENIE CIEĽOV DIZERTAČNEJ PRÁCE

Oblasťou, kde sa prejavuje výrazná výskumná medzera, je plánovanie a trasovanie logistiky v reálnom čase, ktoré zohráva rozhodujúcu úlohu v optimalizácii výrobných a materiálových tokov. Súčasné metódy trasovania logistiky nie sú dostatočne integrované s dynamickými simuláciami, čo spôsobuje nedostatočnú adaptabilitu výrobných procesov pri nepredvídateľných zmenách v prostredí.

Hlavný vedecký problém spočíva v neexistencii komplexnej metodiky, ktorá by umožnila efektívne prepojenie dynamických simulácií s plánovaním a trasovaním logistiky v adaptívnych systémoch. V súčasnosti existujú nasledovné zásadné nedostatky:

- Statickosť existujúcich simulačných modelov – väčšina súčasných simulácií výrobných a logistických procesov vychádza zo statických alebo len čiastočne dynamických modelov, ktoré neumožňujú pružnú adaptáciu na zmeny v layoutoch výrobných systémov s kompetenčnými ostrovmi.
- Obmedzená integrácia reálnych dát do simulačných modelov – v aktuálnych riešeniach chýba kontinuálna aktualizácia simulačných modelov na základe aktuálnych výrobných podmienok. To spôsobuje nepresnosti v rozhodovaní a plánovaní logistických tokov.
- Nedostatok metodiky na prepojenie dynamických simulácií s optimalizačnými algoritmi – existujúce simulačné prístupy nie sú dostatočne prepojené s algoritmi riadenia výroby a logistiky.
- Slabá predikčná schopnosť súčasných modelov.

Na riešenie identifikovaných nedostatkov je potrebné navrhnuť metodiku, ktorá bude kombinovať výhody dynamických simulácií s pokročilými riadiacimi algoritmi na optimalizáciu logistiky adaptívnych systémov. Táto metodika by mala umožniť:

1. Vytvorenie presných digitálnych modelov logistických tokov.
2. Ich nepretržitú aktualizáciu na základe reálnych údajov.
3. Generovanie a implementáciu optimálnych rozhodnutí v reálnom čase.

Očakáva sa, že výsledky práce prinesú zlepšenie efektivity, flexibility a konkurencieschopnosti adaptívnych systémov a prispejú k ich ďalšiemu rozvoju.

2.1 Hlavný cieľ dizertačnej práce

Hlavným cieľom dizertačnej práce je navrhnuť metodiku trasovania pre logistiku adaptívnych systémov v prostredí inteligentného priemyslu.

2.2 Čiastkové ciele

Čiastkovými cieľmi pre metodiku trasovania pre logistiku adaptívnych systémov v prostredí inteligentného priemyslu sú:

- Návrh architektúry trasovania pre logistiku adaptívnych systémov.
- Matematická formulácia optimalizačných problémov.
- Implementačný rámec metodiky.
- Experimentálne overenie navrhnutého riešenia.

3 NÁVRH METODIKY

Metodika je navrhnutá ako modulárny systém pozostávajúci zo siedmich základných funkčných blokov, pričom každý blok reprezentuje uzavretý celok s jasne definovanými vstupmi, výstupmi a rozhodovacími mechanizmami. Tento prístup zabezpečuje škálovateľnosť, udržateľnosť a možnosť vývoja jednotlivých komponentov. Navrhovaná metodika prináša niekoľko zásadných inovácií v oblasti adaptívnych logistických systémov:

Hybridná architektúra algoritmov – systematicky sa kombinuje deterministické trasovanie založené na A-star algoritme s pokročilými technikami strojového učenia.

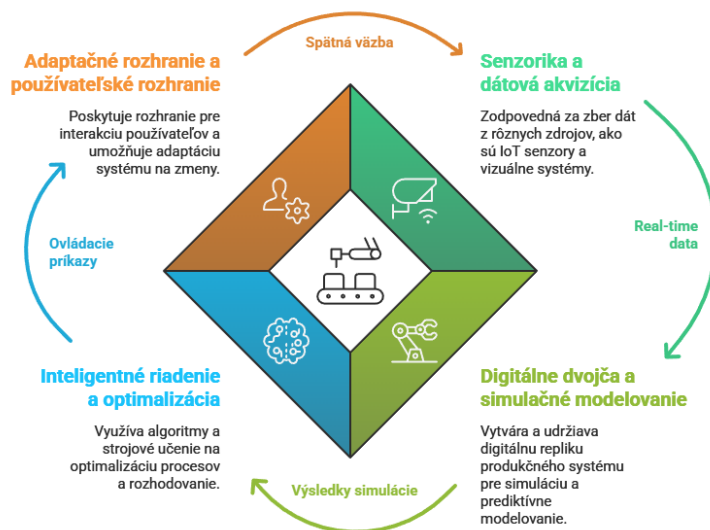
Dynamicky adaptívne digitálne dvojča - na rozdiel od existujúcich simulačných modelov navrhovaný systém implementuje kontinuálne sa aktualizujúce digitálne dvojča, ktoré v reálnom čase reflektuje zmeny vo fyzickom výrobnom prostredí. Integrácia so simulačným prostredím Tecnomatix Plant Simulation umožňuje nielen sledovanie aktuálneho stavu, ale aj prediktívne modelovanie budúcich scenárov s vysokou presnosťou.

Inteligentné rozhodovanie na úrovni križovatiek - metodika zavádza koncept „inteligentných križovatiek“ ako autonómnych rozhodovacích jednotiek schopných lokálneho optimalizovania toku materiálu a informácií.

Viacúrovňová adaptácia - systém implementuje adaptáciu na troch hierarchických úrovniach: operatívnej (sekundy), taktickej (minúty) a strategickej (hodiny/dni). Táto viacúrovňová štruktúra umožňuje optimálnu reakciu na rôzne typy zmien v systéme, od krátkodobých výkyvov až po dlhodobé rekonfigurácie.

3.1 Architektúra systému

Architektúra adaptívneho systému (Obr. 1) je navrhnutá ako hierarchická štruktúra pozostávajúca zo štyroch základných vrstiev, pričom každá vrstva má špecifické zodpovednosti a komunikačné protokoly.



Obr. 1: Architektúra adaptívneho systému (autor, 2025)

3.1.1 Vrstva 1: Senzorika a zber dát

Najnižšia vrstva systému je zodpovedná za zber a primárne spracovanie dát z fyzického prostredia. Táto vrstva zahŕňa široké spektrum senzorov a aktuátorov:

IoT senzorová sieť implementuje distribuovanú architektúru inteligentných senzorov schopných lokálneho spracovania dát a komunikácie prostredníctvom štandardizovaných protokolov.

RFID a NFC systémy zabezpečujú presné sledovanie materiálového toku a identifikáciu objektov v reálnom čase.

Vizuálne systémy zahŕňajú vysokorýchlostné kamery s pokročilými algoritmi počítačového videnia pre detekciu objektov, rozpoznávanie vzorov a sledovanie pohybu.

Environmentálne monitorovanie sleduje podmienky prostredia (teplota, vlhkosť, vibrácie, akustické emisie) s cieľom včasnej detekcie anomálií a predikcie potreby preventívnej údržby.

3.1.2 Vrstva 2: Digitálne dvojča a simulačné modelovanie

Druhá vrstva implementuje koncept digitálneho dvojčaťa ako virtuálnej repliky fyzického produkčného systému. Táto vrstva je kľúčová pre prediktívne schopnosti systému a optimalizáciu rozhodovacích procesov.

Simulačný engine je implementovaný v prostredí Tecnomatix Plant Simulation s vlastnými rozšíreniami a knižnicami.

Real-time synchronizácia zabezpečuje kontinuálnu aktualizáciu simulačného modelu na základe dát zo sensorovej vrstvy. Synchronizácia je implementovaná pomocou udalostne riadenej architektúry s informačným oneskorením pod 100 milisekúnd.

Prediktívne modelovanie využíva pokročilé algoritmy strojového učenia pre prognózovanie budúcich stavov systému s horizontom predikcie 5-60 minút.

Validácia modelu a kalibrácia zabezpečuje presnosť simulačného modelu prostredníctvom kontinuálneho porovnávania predpovedí s reálnymi dátami a automatickej korekcie modelových parametrov.

3.1.3 Vrstva 3: Inteligentné riadenie a optimalizácia

Tretia vrstva predstavuje „mozog“ systému, kde sa realizujú všetky rozhodovacie procesy a optimalizačné algoritmy.

Trasovací engine implementuje hybridný prístup kombinujúci deterministické algoritmy (A-star, Dijkstra) s technikami posilňovaného učenia.

Multi-kriteriálny optimalizátor rieši zložité optimalizačné úlohy s viacerými konkurenčnými cieľmi (minimalizácia času, nákladov, energetickej spotreby, maximalizácia priepustnosti).

Rozhodovací subsystém je implementovaný ako hybridný expertný systém kombinujúci dôvodenie založené na pravidlách s fuzzy logikou a pravdepodobnostnými metódami.

Machine Learning platforma poskytuje podporu pre kontinuálne učenie systému prostredníctvom algoritmov online učenia.

3.1.4 Vrstva 4: Rozhranie pre adaptívne riadenie a vizualizáciu výroby

Najvyššia vrstva zabezpečuje interakciu s externými systémami a používateľmi, implementuje adaptačné mechanizmy a poskytuje nástroje pre konfiguráciu a monitorovanie systému.

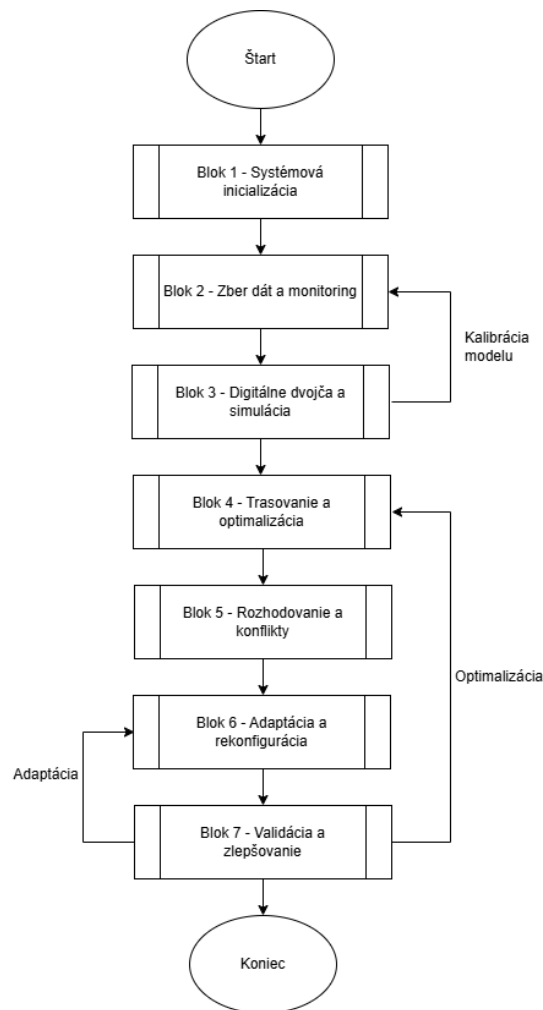
Adaptačný engine monitoruje výkonnostné charakteristiky systému a implementuje zmeny v konfigurácii, algoritmických parametroch a štruktúre systému.

API Gateway poskytuje štandardizované rozhranie pre integráciu s externými systémami (ERP, MES, WMS) prostredníctvom rôznych komunikačných protokolov.

Dashboard a vizualizácia implementuje interaktívne používateľské rozhranie pre monitoring, konfiguráciu a ovládanie systému.

Reporting a analytika poskytuje pokročilé analytické nástroje pre vyhodnocovanie výkonnosti systému, identifikáciu trendov a generovanie reportov pre rôzne úrovne manažmentu.

3.2 Metodika sedemblokového prístupu

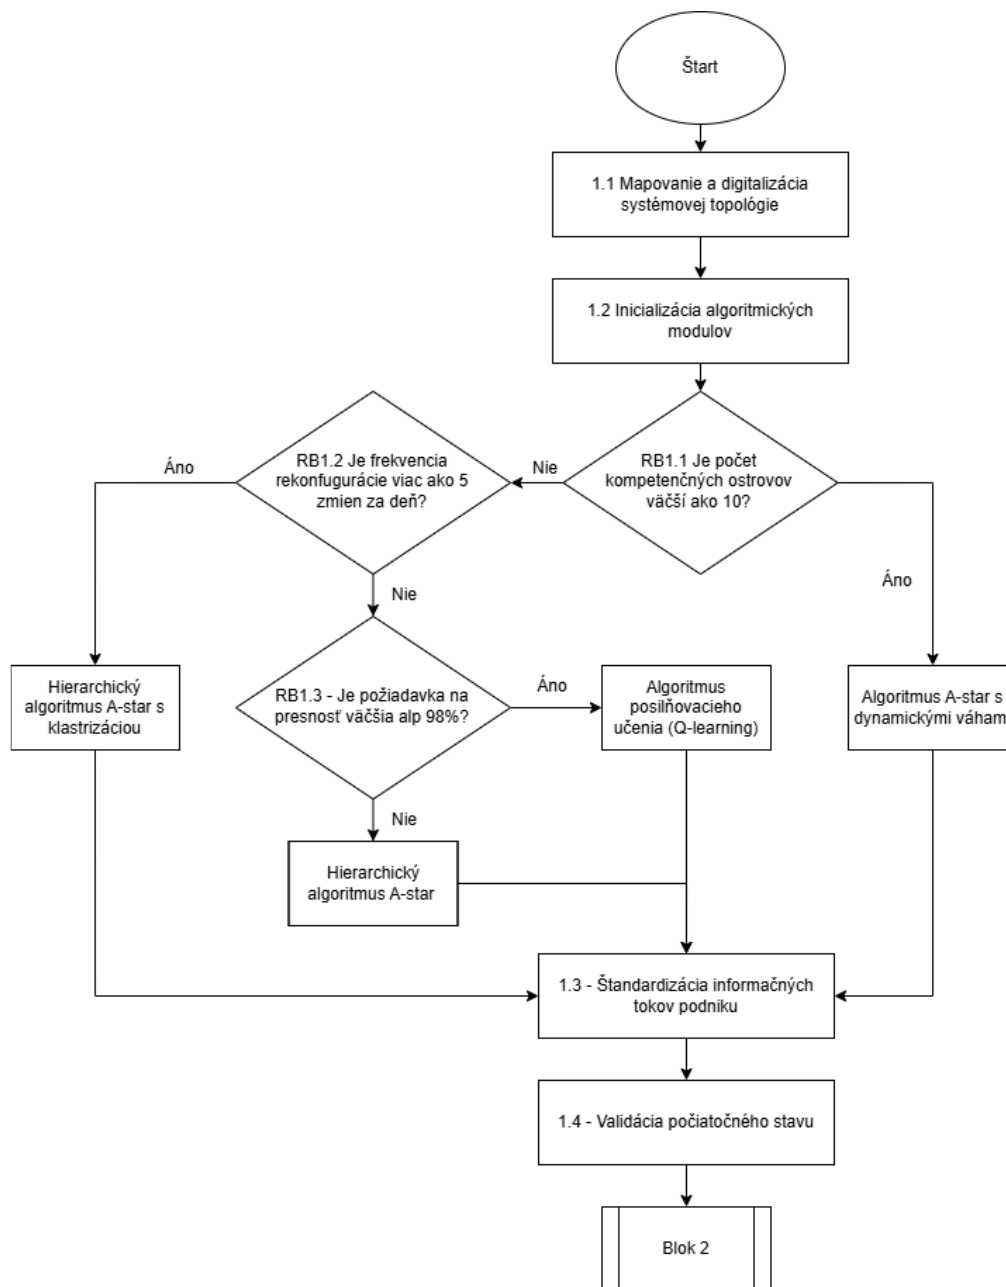


Obr. 2: Štruktúra sedemblokového prístupu (autor, 2025)

Navrhovaná metodika adaptívneho riadenia je koncipovaná ako modulárny rámec pozostávajúci zo siedmich funkčných blokov. Tento prístup bol zvolený s cieľom zabezpečiť vysokú mieru flexibility, transparentnosti a jednoduchú modifikovateľnosť systému v simulačnom prostredí. Hlavným prínosom modulárnej štruktúry je separácia dátových vstupov, rozhodovacej logiky a simulačného jadra. Postupový diagram sedemblokového prístupu je zobrazený na Obr. 2.

3.2.1 Blok 1: Systémová inicializácia a mapovanie topológie

Prvým krokom metodiky je vytvorenie presného digitálneho obrazu fyzického systému. Blok inicializácie zabezpečuje naštartovanie simulačného modelu. Definuje počiatočné pozície AGV vozíkov a mapuje aktuálny layout kompetenčných ostrovov. Tieto dáta sú vstupné parametre pre výpočet matice vzdialeností. Postupový diagram bloku 1 je zobrazený na Obr. 3.



Obr. 3: Blok 1 – Systémová inicializácia a mapovanie topológie (autor, 2025)

Podproces 1.1: Mapovanie a digitalizácia systémovej topológie - načítanie systémovej topológie predstavuje kritický proces, ktorý vytvára digitálnu reprezentáciu fyzického prostredia. Tento podproces zabezpečuje automatizované objavovanie zariadení a tvorbu grafovej reprezentácie výrobného priestoru.

Podproces 1.2: Inicializácia algoritmických modulov - inicializácia algoritmických modulov implementuje sofistikovaný rozhodovací proces pre výber optimálneho algoritmu na základe charakteristík systému a požiadaviek aplikácie.

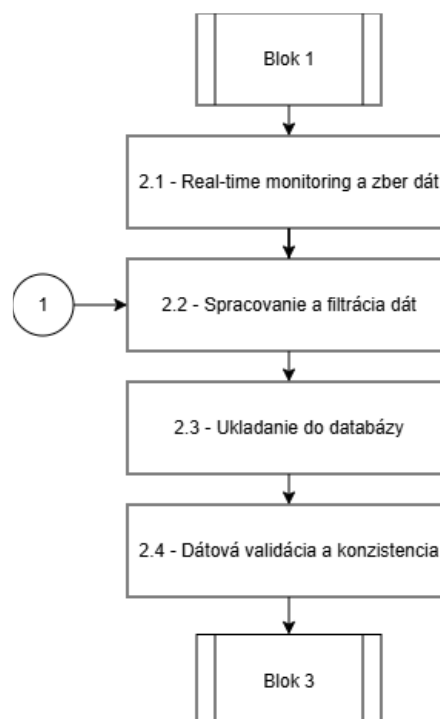
Rozhodovací bod RB1: Výber a inicializácia riadiaceho algoritmu - tento rozhodovací bod implementuje hierarchický rozhodovací strom, ktorý na základe kvantitatívnych metrík vyberie najvhodnejší algoritmický prístup.

Podproces 1.3: Štandardizácia informačných tokov podniku - konfigurácia komunikačných protokolov zabezpečuje spoľahlivú a bezpečnú komunikáciu medzi všetkými komponentmi systému.

Podproces 1.4: Validácia počiatočného stavu - validácia počiatočného stavu implementuje komplexný testovací rámec pre overenie správnej funkčnosti všetkých komponentov systému.

3.2.2 Blok 2: Zber dát a monitoring

Blok 2 predstavuje zmyslový orgán systému. Jeho úlohou je zabezpečiť transformáciu surových fyzických signálov na sémanticky významné informácie pre digitálne dvojča. Postupový diagram bloku 2 je zobrazený na Obr. 4.



Obr. 4: Blok 2 - Zber dát a monitoring (autor, 2025)

Podproces 2.1: Real-time monitoring a zber dát - implementuje sa viacvrstvová architektúra zberu dát využívajúca decentralizované spracovanie dát priamo na pracovisku pre redukciu informačného oneskorenia.

Podproces 2.2: Spracovanie a filtrácia dát - spracovanie a filtrácia dát implementuje pokročilé algoritmy pre čistenie, transformáciu a obohatenie surových senzorických dát. Surové dáta z výroby sú často zašumené alebo neúplné.

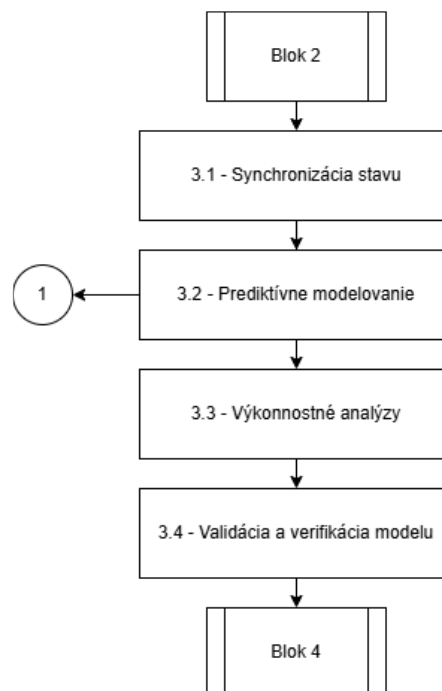
Podproces 2.3: Ukladanie do databázy - ukladanie do databázy implementuje architektúru distribuovaného úložiska optimalizovanú pre dáta zozbierané v časových intervaloch s vysokými požiadavkami na rýchlosť zápisu a rýchlosť spracovania.

Podproces 2.4: Dátová validácia a konzistencia - dátová validácia implementuje viacvrstvový validačný rámec pre zabezpečenie kvality a integrity dát:

- Syntaktická kontrola
- Sémantická kontrola
- Krížová kontrola
- Systém hodnotenia kvality dát

3.2.3 Blok 3: Digitálne dvojča a prediktívna simulácia

Tento blok (Obr. 5) udržiava virtuálnu kópiu systému, ktorá slúži nielen na monitorovanie, ale najmä na predikciu budúcich stavov.



Obr. 5: Blok 3 - Digitálne dvojča a prediktívna simulácia (autor, 2025)

Podproces 3.1: Synchronizácia stavu - aktualizácia simulačného modelu implementuje udalosťami riadenú architektúru pre efektívnu synchronizáciu medzi fyzickým a digitálnym dvojčatom. Real-time synchronizácia využíva mechanizmy zachytávania zmien v dátach pre okamžité odrážanie zmien z fyzického systému do simulačného modelu.

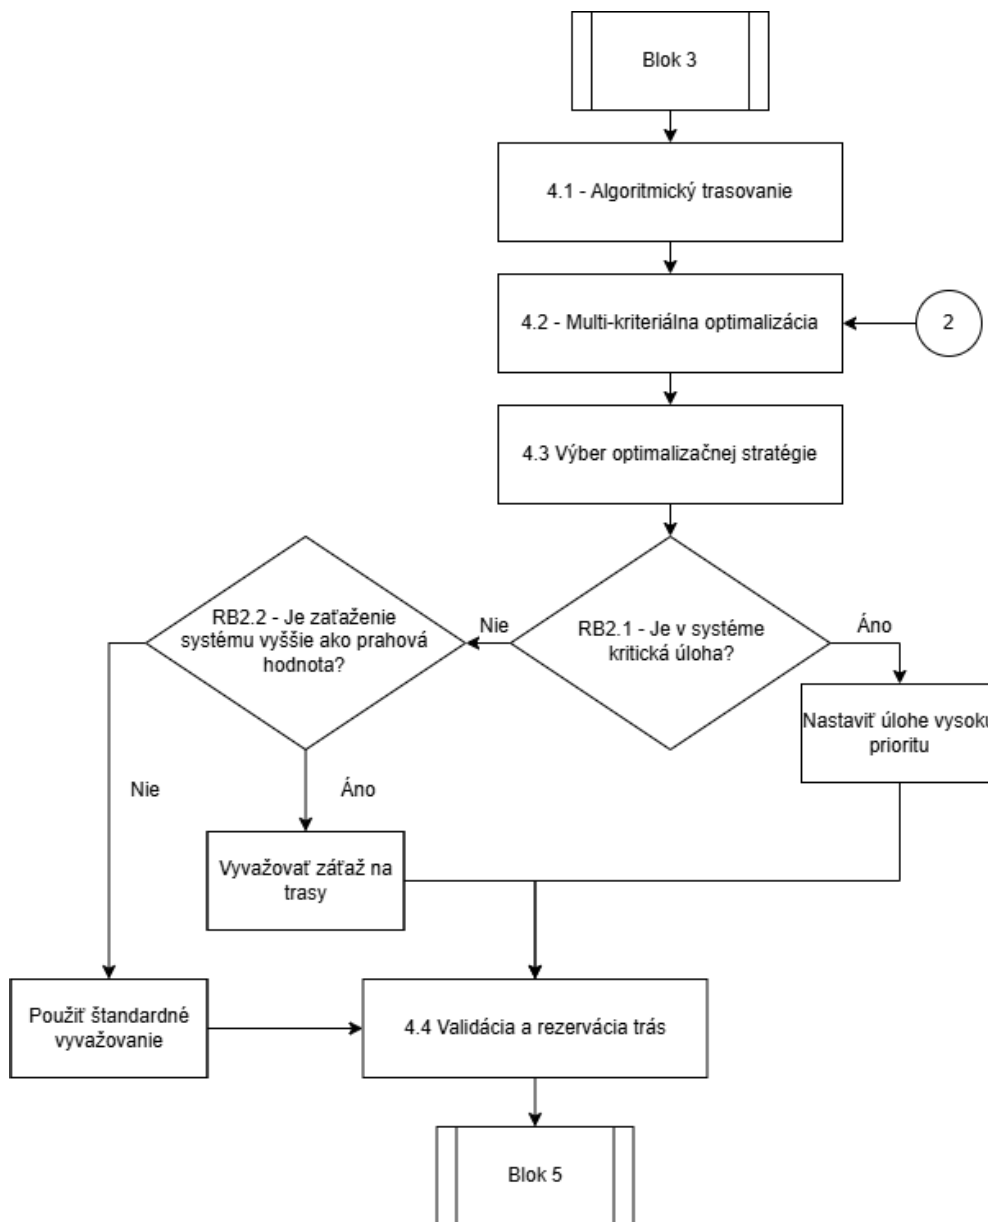
Podproces 3.2: Prediktívne modelovanie - prediktívne modelovanie implementuje schopnosti pokročilého forecastingu využívajúce machine

Podproces 3.3: Výkonnostné analýzy - výkonnostné analýzy implementujú komplexný analytický rámec pre porozumenie výkonu v systéme a identifikáciu optimalizačných príležitostí. Analýza priepustnosti systému využíva detailné skúmanie toku dát alebo procesov s identifikáciou kritických ciest a kapacitných obmedzení.

Podproces 3.4: Validácia a verifikácia modelu - na validáciu a verifikáciu modelu sa využíva dôkladný testovací rámec, ktorý zabezpečuje presnosť a spoľahlivosť predikčných a analytických modelov:

- Štatistická validácia.
- Krížová validácia.
- Analýza citlivosti.
- Kvantifikácia neistoty.

3.2.4 Blok 4: Inteligentné trasovanie a optimalizácia logistiky



Obr. 6: Blok 4 - Inteligentné trasovanie a optimalizácia logistiky (autor, 2025)

Štvrtý blok obsahuje základné algoritmy pre plánovanie trás a optimalizáciu pohybu v dynamicky sa meniacich prostrediach. Na základe dát z digitálneho dvojčata tento blok generuje konkrétne príkazy pre pohyb materiálu. Obr. 6 zobrazuje postupový diagram bloku 4.

Podproces 4.1: Algoritmické trasovanie - algoritmické trasovanie využíva hybridný prístup, ktorý kombinuje viacero algoritmov, aby sa dosiahol optimálny výkon v rôznych scenároch. A-star implementácia využíva optimalizovaný A-star algoritmus s vlastnými heuristickými funkciami prispôbenými výrobnej prevádzke. Systém podporuje dynamické aktualizácie nákladov a preplánovanie trás podľa aktuálnej situácie.

Podproces 4.2: Multi-kriteriálna optimalizácia - multi-kriteriálna optimalizácia rieši problémy, pri ktorých je potrebné súčasne zohľadniť viacero často protichodných cieľov. Pareto optimalizácia využíva algoritmus na hľadanie riešení, ktoré sú Pareto-optimalne a umožňujú vyvážiť viacero cieľov, ako sú čas, náklady, energia a kvalita. Prístup váženého súčtu využíva dynamickú úpravu váh podľa aktuálnych priorít systému a obchodných cieľov. Programovanie cieľov využíva prístup na riešenie problémov, ktorý umožňuje pracovať s cieľmi usporiadanými podľa prísnej priority.

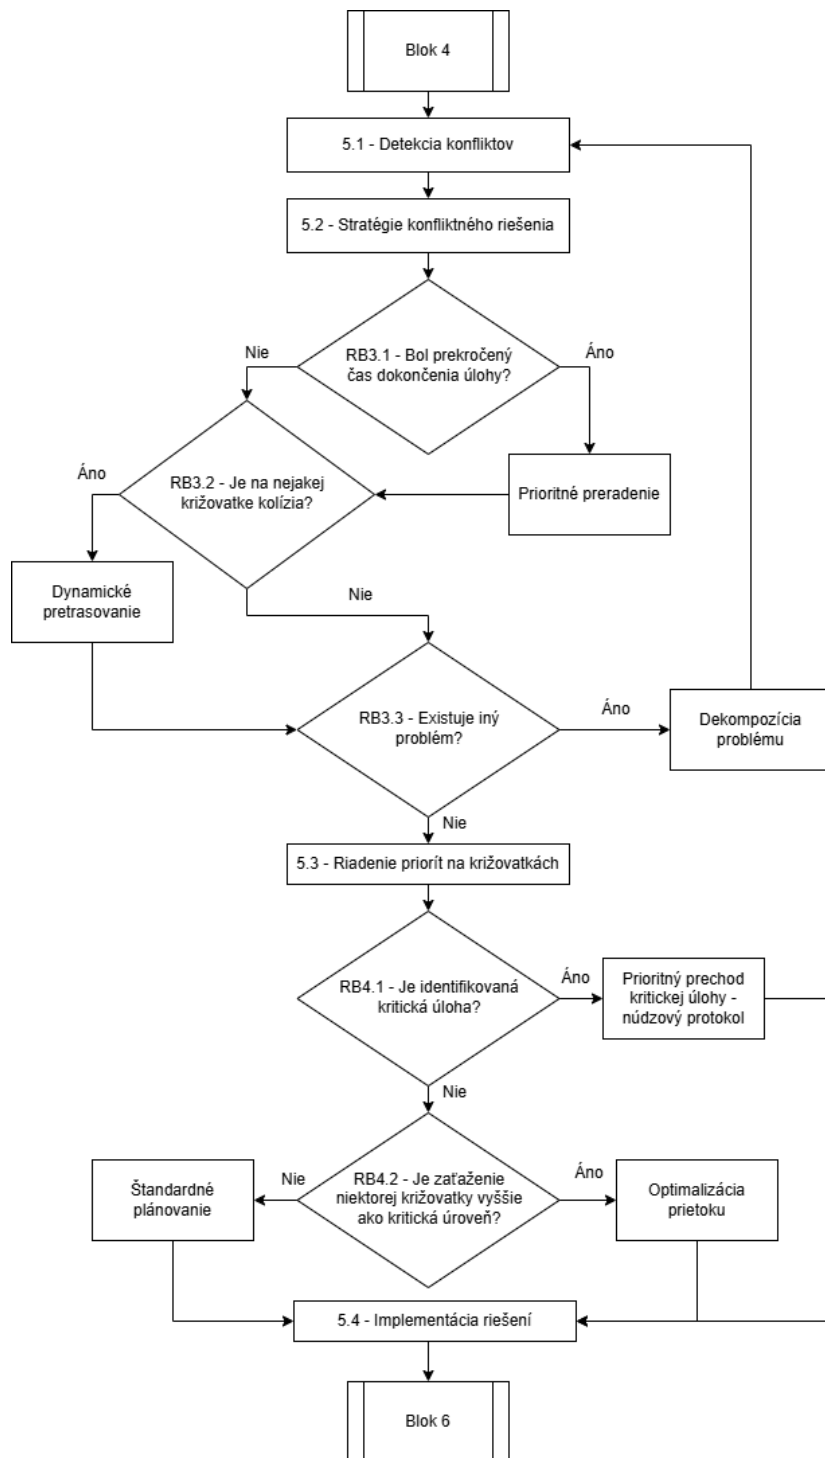
Podproces 4.3: Výber optimalizačnej stratégie - rozhodovací bod RB2 tu bude implementovať inteligentné zvolenie stratégie pre plánovanie trás na základe aktuálnych podmienok.

Rozhodovací bod RB2: Výber optimalizačnej stratégie - riešenie kritických úloh využíva plánovanie s prioritami a rezerváciu zdrojov pre najdôležitejšie úlohy. Tento prístup zaručuje dodržanie termínov pre vysoko prioritné operácie. Stratégia vyváženia záťaže zabezpečuje inteligentné rozdeľovanie záťaže naprieč viacerými trasami s cieľom predchádzať úzkym miestam a maximalizovať priepustnosť systému. Štandardná optimalizácia využíva vyvážený prístup, ktorý optimalizuje viacero kritérií pri zachovaní primeranej výpočtovej náročnosti.

Podproces 4.4: Validácia a rezervácia tras - validácia a rezervácia implementuje robustné mechanizmy pre zabezpečenie priechodnosti trasy a dostupnosti zdrojov.

3.2.5 Blok 5: Rozhodovanie a riešenie konfliktov v reálnom čase

Piaty blok obsahuje pokročilé mechanizmy rozhodovania a riešenia konfliktov, ktoré umožňujú efektívne zvládať zložité scenáre. Zatiaľ čo blok 4 plánuje globálne, Blok 5 rieši lokálne interakcie, aby sa predišlo kolíziám. Postupový diagram bloku 5 je zobrazený na Obr. 7.



Obr. 7: Blok 5 - Rozhodovanie a riešenie konfliktov v reálnom čase (autor, 2025)

Podproces 5.1: Detekcia konfliktov - detekcia konfliktov implementuje proaktívny monitoring a systém skorého upozornenia pre potenciálne problémy.

Podproces 5.2: Stratégie riešenia konfliktov - rozhodovací bod RB3 tu bude implementovať inteligentný systém výberu stratégie riešenia konfliktov.

Rozhodovací bod RB3: Stratégie riešenia konfliktov - dynamické preplánovanie trás zabezpečuje prepočet trás v reálnom čase s minimálnym narušením existujúcich operácií a zohľadňuje kaskádové

efekty na ostatné činnosti. Prioritné preradenie implementuje inteligentné zvyšovanie priority úloh s ohľadom na spravodlivosť, čím sa predchádza zanedbaniu úloh s nižšou prioritou. Dekompozícia problémov rozkladá zložité konflikty na zvládnuteľné podproblémy a využíva hierarchický prístup k ich riešeniu.

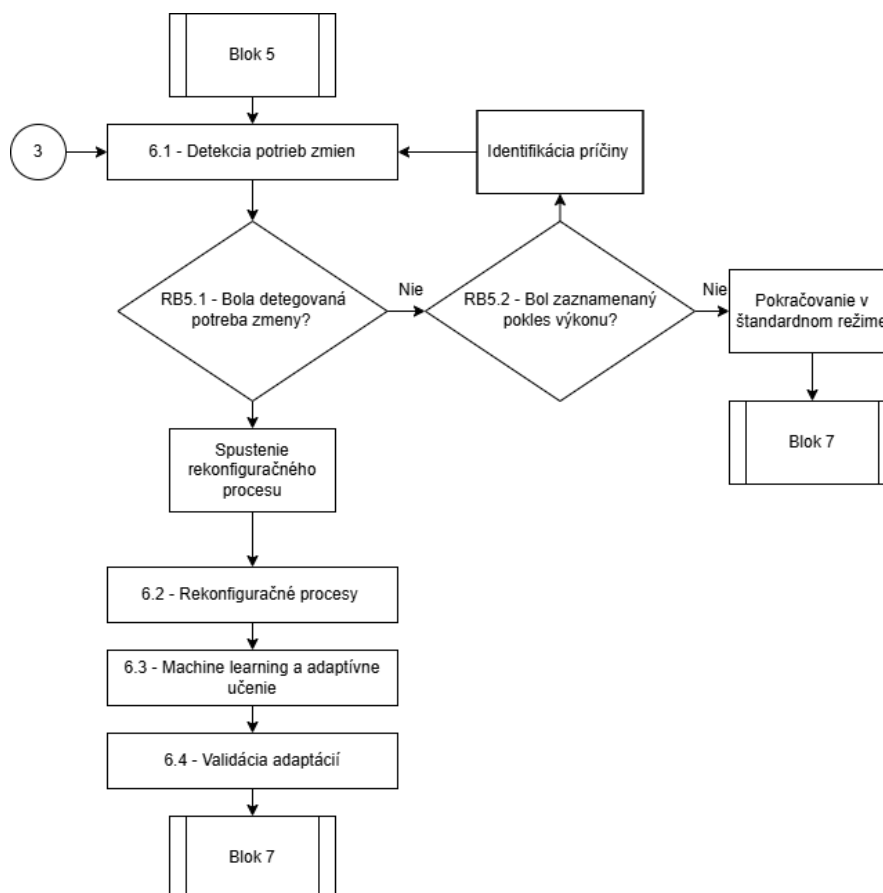
Podproces 5.3: Riadenie priorít na križovatkách - rozhodovací bod RB4 tu bude implementovať systém inteligentného riadenia križovatiek prispôsobený pre prostredie výroby.

Rozhodovací bod RB4: Riadenie priorít na križovatkách - núdzové protokoly zabezpečujú okamžitú reakciu v kritických situáciách a majú prednosť pred bežnou dopravou, aby sa umožnil rýchly prístup v núdzových prípadoch. Optimalizácia prietoku využíva inteligentné algoritmy riadenia semaforov, ktoré sú optimalizované na minimalizáciu čakacích dôb a maximalizáciu priepustnosti. Štandardné plánovanie implementuje spravodlivé plánovanie úloh s ohľadom na priority, čím sa dosahuje rovnováha medzi efektívnosťou a spravodlivosťou.

Podproces 5.4: Implementácia riešení - implementovanie opatrení na riešenie konfliktov s možnosťou návratu späť v prípade zlyhania.

3.2.6 Blok 6: Adaptácia a evolúcia systému

Šiesty blok implementuje inteligentné adaptačné mechanizmy umožňujúce systému vyvíjať sa a zlepšovať sa v čase. Zabezpečuje dlhodobé učenie a prispôsobovanie sa meniacim sa podmienkam. Postupový diagram bloku 6 je vyobrazený na Obr. 8.



Obr. 8: Blok 6 - Adaptácia a evolúcia systému (autor, 2025)

Podproces 6.1: Detekcia potrieb zmien - rozhodovací bod RB5 tu bude implementovať sofistikované mechanizmy detekcie zmien a podmieňovania adaptácie. Ak dlhodobý trend výkonnosti klesne pod prahovú hodnotu, alebo ak sa zmení konfigurácia výroby, systém vyvolá požiadavku na rekonfiguráciu.

Rozhodovací bod RB5: Potreba zmeny - monitorovanie výkonu implementuje kontinuálne monitorovanie kľúčových výkonnostných ukazovateľov s podporou trendovej analýzy a detekcie anomálií. Zabezpečuje priebežné vyhodnocovanie efektivity systémových rozhodnutí a poskytuje podklady pre adaptívne úpravy riadiacich algoritmov.

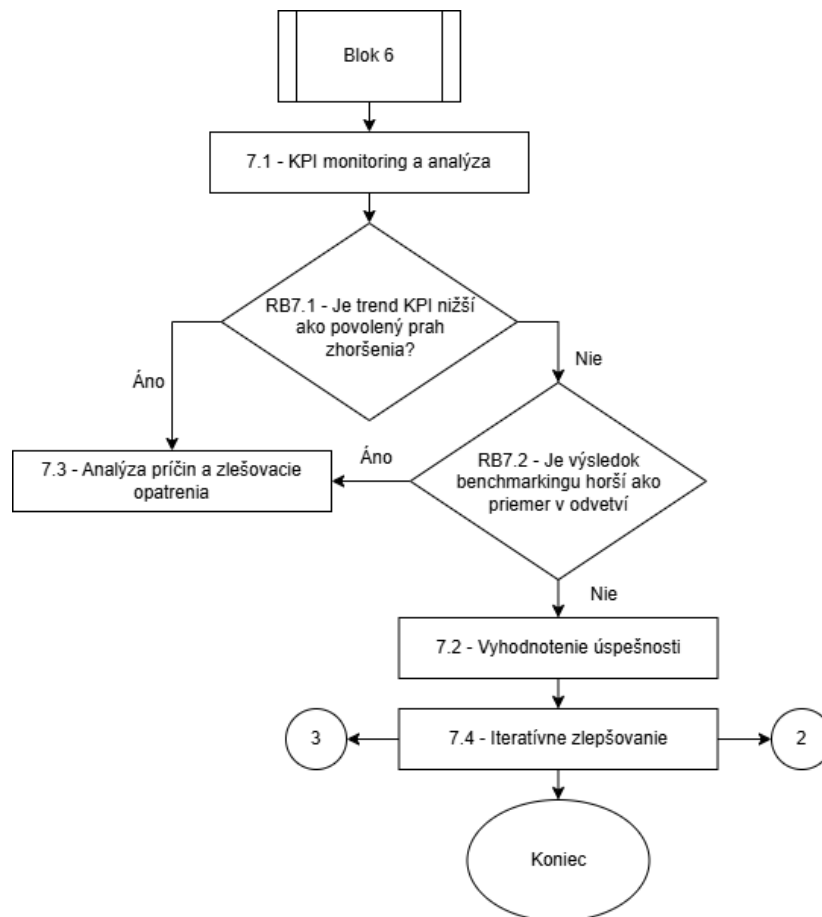
Podproces 6.2: Rekonfiguračné procesy - rekonfiguračné procesy implementujú kontrolované riadenie zmien s minimálnym narušením operácií.

Podproces 6.3: Machine Learning a adaptívne učenie - machine Learning komponenty implementujú schopnosti neustáleho vzdelávania pre zlepšovanie systému.

Podproces 6.4: Validácia adaptácií - validácia adaptácií zabezpečuje efektivitu a bezpečnosť adaptačných zmien.

3.2.7 Blok 7: Validácia a kontinuálne zlepšovanie

Siedmy blok implementuje komplexné zabezpečenie kvality a neustále zlepšovanie. Postupový diagram bloku 7 je zobrazený na Obr. 9.



Obr. 9: Blok 7 - Validácia a kontinuálne zlepšovanie (autor, 2025)

Podproces 7.1: KPI monitoring a analýza - rozhodovací bod RB6 tu bude implementovať inteligentný spúšťač systém pre neustále zlepšovanie.

Rozhodovací bod RB6: Spúšťač bod pre zlepšovanie systému

KPI dashboard implementuje real-time vizualizáciu kľúčových výkonnostných indikátorov s podporou analýz pre detailné skúmanie jednotlivých metrik. Umožňuje okamžité zisťovanie trendov a identifikáciu odchýlok od očakávaného výkonu.

Analýza trendov využíva štatistické metódy a machine learning pre identifikáciu dlhodobých trendov a predikciu budúceho správania systému. Podporuje strategické plánovanie a proaktívne riadenie výkonu.

Benchmarking porovnáva výkonnosť systému voči priemyselným štandardom a predchádzajúcim verziám. Identifikuje oblasti s potenciálom zlepšenia a kvantifikuje rozdiel medzi aktuálnym stavom a cieľovou úrovňou výkonnosti.

Analýza koreňových príčin implementuje systematický prístup k identifikácii koreňových príčin výkonnostných problémov. Podporuje preventívne opatrenia, ktoré eliminujú príčiny, nie iba následky.

Podproces 7.2: Vyhodnotenie úspešnosti - rozhodovací bod implementuje komplexný rámec hodnotenia kritérií úspešnosti.

Podproces 7.3: Analýza príčin a zlepšovacie opatrenia - analýza príčin implementuje systematický prístup pre porozumenie výkonnostných problémov a vývoj stratégií zlepšovania. Využívajú sa tieto nástroje:

- Analýza rybej kosti.
- Pareto analýza.
- Analýza 5x prečo.
- Štatistická kontrola procesov.

Podproces 7.4: Iteratívne zlepšovanie - iteratívne zlepšovanie implementuje kultúru kontinuálneho zlepšovania s štruktúrovaný prístup pre zlepšovanie systému. Využívajú sa tieto metódy:

- Plan-Do-Check-Act cyklus.
- Kaizen prístup.
- Proces inovácií.
- Manažment znalostí.

4 EXPERIMENTÁLNE OVERENIE NAVRHOVANÉHO RIEŠENIA

Predmetom experimentálneho overenia je simulačný model, ktorý reprezentuje výrobný systém s vysokou variabilitou dopytu. Priestorové usporiadanie tohto virtuálneho podniku je koncipované na báze kompetenčných ostrovov. Fyzická vrstva systému pozostáva z ôsmich špecializovaných kompetenčných ostrovov a maticovej logistickej siete s 24 križovatkami a 48 dopravnými segmentmi. Obsluhu materiálového toku zabezpečuje flotila 1 až 30 AGV s definovanou kinematikou.

4.1 Ciele experimentu a hypotézy


Hlavným cieľom je potvrdiť, že integrácia digitálneho dvojčaťa a dynamickej optimalizácie vedie k signifikantnému zlepšeniu kľúčových výkonnostných ukazovateľov (KPI).

Definované hypotézy:

- **Hypotéza 1:** Adaptívny systém riadenia dosiahne minimálne o 15% vyššiu priepustnosť v porovnaní s tradičným systémom pri rovnakých zdrojoch.
- **Hypotéza 2:** Aplikácia prediktívneho riešenia konfliktov eliminuje výskyt mŕtvych bodov v dopravnej sieti.
- **Hypotéza 3:** Systém dokáže zareagovať na kritickú poruchu na trase do 3 sekúnd a stabilizovať výrobu s minimálnym dopadom na priebežnú dobu prioritných zákaziek.

4.2 Simulačný model

Pre emuláciu fyzickej vrstvy adaptívneho logistického systému a realizáciu experimentov bol zvolený softvérový nástroj Tecnomatix Plant Simulation. Priestorové usporiadanie virtuálneho podniku a rozloženie kompetenčných ostrovov v maticovej sieti demonštruje Obr. 10.



Obr. 10: 3D simulačný model (autor, 2026)

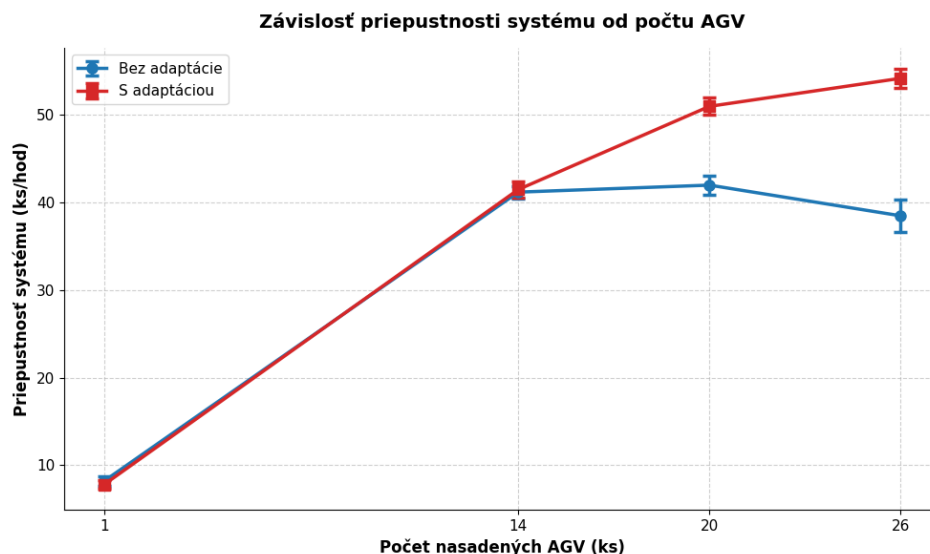
Prepojenie navrhutej metodiky so simulačným prostredím Plant Simulation bolo vytvorené tak, že samotné rozhodovacie algoritmy fungujú ako samostatný externý program. So simuláciou sú prepojené cez rozhrania a neustále si medzi sebou vymieňajú aktuálne dáta o stave výroby. Toto oddelenie má tú výhodu, že zabezpečuje, že táto metodika riadenia nie je pevne zviazaná len s jedným konkrétnym softvérom, ale je možné ju v budúcnosti jednoducho prepojiť s iným simulačným programom alebo priamo s reálnou továrňou.

Pred spustením hlavných experimentov bolo nutné sériou konkrétnych testov preukázať, že vytvorený model v prostredí Plant Simulation neobsahuje programátorské chyby (verifikácia) a že sa jeho správanie zhoduje s logikou reálnych výrobných systémov (validácia).

4.3 Scenár A: Štandardná prevádzka a hľadanie úzkeho miesta

Tento scenár predstavuje základnú rovinu pre posúdenie stability a priepustnosti systému pri konštantnom (nominálnom) prísune zákaziek. Hlavným cieľom bolo identifikovať kritické úzke miesta v logistickej sieti a exaktne preukázať, v ktorom bode hustoty premávky dochádza k degradácii výkonu pri použití štandardného statického riadenia. Počas experimentu sa postupne zvyšoval počet alokovaných AGV v systéme od 1 AGV až po stav preťaženia (26 vozidiel), pričom prísun zákaziek zostal nezmenený.

Z grafu (Obr. 11) vyplývajú dva zásadné závery. Pri nízkom počte vozidiel (do 14 AGV) sieť logicky nie je saturovaná a oba algoritmy dosahujú štatisticky zhodné výsledky.




Obr. 11: Závislosť priepustnosti systému od počtu AGV (autor, 2026)

Kritický zlom však nastáva pri prechode do nominálneho stavu a následného preťaženia. Pri 20 vozidlách Q-learning úspešne zvyšuje priepustnosť na 51 ks/hod oproti 42 ks/hod pri statickom riadení, čo predstavuje signifikantné zlepšenie o 21,43%. Pri extrémnom zaťažení (26 AGV) statický algoritmus naráža na svoje kapacitné limity a priepustnosť systému začína paradoxne klesať (na 38,5 ks/hod) v dôsledku vzájomného blokovania vozidiel a extrémneho nárastu procesnej variability (smerodajná odchýlka vzrástla na 3,8). Naopak, hybridný algoritmus Q-learning dokáže vďaka autonómnemu rozkladu záťaže na suboptimálne, ale voľné obchádzkové trasy udržať rastový trend.

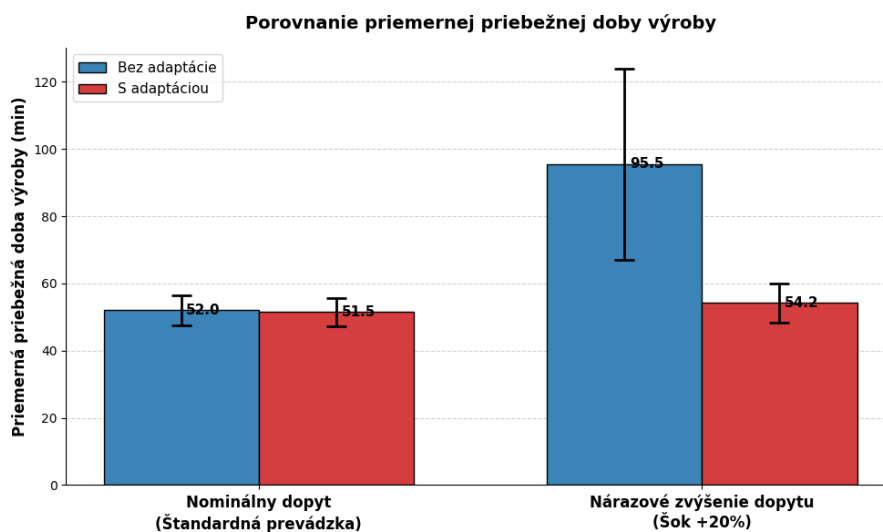
4.4 Scenár B: Nárazové zvýšenie dopytu

Tento experimentálny scenár bol navrhnutý na testovanie robustnosti a adaptability logistického systému pri skokovom preťažení. V rámci simulačného experimentu bol prísun zákaziek skokovo zvýšený o 20% nad nominálnu kapacitu systému, pričom sa analyzovala schopnosť adaptívnej metodiky proaktívne rozdeliť prácu medzi alternatívne kompetenčné ostrovy.



Obr. 12: Porovnanie rozptylu rozpracovanej výroby pri nárazovom dopyte (autor, 2026)

Výsledky analýzy rozpracovanej výroby (Obr. 12) demonštrujú zásadný rozdiel v správaní oboch algoritmov. Deterministický algoritmus A-star pokračoval v striktnej alokácii požiadaviek na primárne (priestorovo najkratšie) trasy, čo pri zvýšenom dopyte spôsobilo okamžité prepĺnenie vstupných zásobníkov v kritických uzloch. Tento jav sa prejavil nielen nárastom strednej hodnoty rozpracovanej výroby, ale najmä jej extrémnou variabilitou (široké medzikvartilové rozpätie a prítomnosť odľahlých hodnôt). Naopak, adaptívny systém riadený Q-learningom dokázal vďaka včasnej identifikácii rastúcej záťaže dynamicky presmerovať toky materiálu na menej vyťažené, hoci priestorovo vzdialenejšie kompetenčné ostrovy.



Obr. 13: Porovnanie priemernej priebežnej doby výroby a jej variability (autor, 2026)


Ako potvrdzuje Littleov zákon, stabilizácia rozpracovanej výroby mala priamy pozitívny dopad na priebežnú dobu výroby (Obr. 13). Kým v klasickom systéme narástla priebežná doba pri 20% šoku do neakceptovateľných hodnôt s obrovským rozptylom, Q-learning dokázal absorbovať tento šok s minimálnou degradáciou časových metrík.

4.5 Scenár C: Porucha kritického uzla

Tretí experimentálny scenár bol navrhnutý ako záťažový test prevádzkovej odolnosti adaptívneho systému. Cieľom tohto scenára bolo otestovať reakčný čas systému na náhlu, nepredvídateľnú poruchu najviac vyťaženého dopravného uzla priamo počas prevádzkovej špičky, a exaktne vyhodnotiť schopnosť algoritmov autonómne prepočítať obchádzkové trasy bez nutnosti zastavenia výroby.

Pri použití deterministického riadenia (algoritmus A-star) znamenal výpadok kritického uzla okamžité prerušenie materiálového toku. Keďže tradičný systém nedisponuje mechanizmom pre dynamickú aktualizáciu váh hrán v grafe na základe udalostí v reálnom čase, AGV smerujúce cez daný uzol zostali zablokované v nekonečnej slučke čakania, čo viedlo k reťazovému zlyhaniu a rapídному nárastu počtu čakajúcich vozidiel.

Na exaktné preukázanie rozdielu v správaní bol z exportovaných dát simulácie (z 15 nezávislých replikácií) zrekonštruovaný časový rad vývoja počtu čakajúcich AGV bezprostredne po vzniku poruchy.



Obr. 14: Vývoj počtu čakajúcich AGV po kritickej poruche (autor, 2026)

Ako demonštruje graf (Obr. 6.10), v simulačnom čase $t = 120$ min, kedy bola simulovaná porucha uzla, dochádza pri oboch prístupoch k okamžitému a strmému nárastu počtu čakajúcich vozidiel. Zásadný rozdiel však nastáva v čase detekcie a reakcie. Zatiaľ čo pri tradičnom systéme fronta čakajúcich AGV exponenciálne rastie až do úplného kolapsu siete, hybridný systém riadený Q-learningom dokázal anomáliu okamžite detegovať.

4.6 Celkové štatistické zhodnotenie

Na finálnu kvantifikáciu rozdielov vo výsledkoch bola spracovaná súhrnná tabuľka (Tab. 1) relatívneho zlepšenia výkonnosti naprieč všetkými testovanými scenármi.

Tab. 1: Zmeny v kľúčových metrikách (autor, 2026)

Výkonnostný ukazovateľ (KPI)	Scenár	Výsledok Baseline (A-star)	Výsledok Navrhnutý systém (Q-learning)	Percentuálna zmena	Hodnotenie dopadu
Priepustnosť (ks/hod)	B (Preťaženie)	42	51	+ 21,43%	Signifikantné zlepšenie
Priemerná čakacia doba (s)	A (Hustá premávka)	145,2	84,6	- 41,73%	Signifikantné zlepšenie
Variabilita WIP (Rozptyl)	B (Preťaženie)	Vysoká	Stabilná	- 30,00%	Zvýšenie predvídateľnosti
Reakčný čas na poruchu (s)	C (Výpadok uzla)	Zlyhanie	1,21	N/A	Získanie resiliencie
Celková spotreba AGV (kWh)	A, B, C (Priemer)	48,5	52,1	+ 7,42%	Mierne zhoršenie

4.7 Závěry z experimentálneho overenia

Na základe zrealizovaných experimentov a rozsiahlej dátovej analýzy je možné objektívne vyhodnotiť stanovené hypotézy a definovať hranice aplikovateľnosti navrhutej metodiky adaptívneho riadenia.

Experimentálne merania potvrdili platnosť všetkých troch stanovených hypotéz:

- Hypotéza 1 (Priepustnosť):** Bola potvrdená. Adaptívny systém riadený Q-learningom pri skokovom náraste dopytu (Scenár B) preukázal signifikantné zlepšenie priepustnosti o 21,43% (z priemerných 42 ks/hod na 51 ks/hod). Grafy hlavných efektov však túto hypotézu dôležito spresnili: prínos adaptívneho trasovania sa prejavuje nelineárne a jeho dominancia nastáva predovšetkým pri vysokej hustote dopravy (preťaženie siete), zatiaľ čo pri poloprázdnom systéme sa výkonnosť oboch prístupov štatisticky nelíši.
- Hypotéza 2 (Eliminácia uviaznutí):** Bola potvrdená. Aplikácia prediktívneho riešenia konfliktov nielenže úplne eliminovala výskyt mŕtvych bodov, ale analýza rozptylu (vizualizovaná pomocou krabicových grafov) preukázala aj štatisticky významné zníženie variability rozpracovanej výroby. Systém tak dokázal udržať plynulý tok materiálu aj pri záťažovom nasadení 26 a viac AGV.
- Hypotéza 3 (Reakčný čas):** Bola potvrdená. Pri náročnej simulácii kritického výpadku uzla (Scenár C) systém autonómne prepočítal obchádzkové trasy v priemernom čase 1,21 sekundy s úzkou smerodajnou odchýlkou $\pm 0,18$ sekundy. Takto exaktne definovaný 95% interval spoľahlivosti matematicky garantuje vysokú stabilitu, rýchlosť a resilienciu systému voči poruchám.

5 PRÍNOSY DIZERTAČNEJ PRÁCE PRE VEDU A PRAX

Predkladaná dizertačná práca rieši vysoko aktuálnu problematiku adaptívneho riadenia logistických systémov v kontexte paradigmy Priemyslu 4.0. Vzhľadom na prienik teoretických metód systémového inžinierstva, umelej inteligencie a ich následného simulačného testovania v podmienkach blízkych reálnej prevádzke, je možné definovať konkrétne prínosy práce vo dvoch hlavných rovinách: prínosy pre rozvoj teórie a vedy a prínosy pre priemyselnú prax.

7.1 Prínosy pre rozvoj vedného odboru

Z vedeckého hľadiska práca obohacuje teóriu kyberneticko-fyzikálnych systémov a multi-agentových systémov. Dôležitým vedeckým prínosom je prechod od reaktívnych a statických modelov k proaktívnym, učiacim sa štruktúram. Konkrétne teoretické prínosy sú nasledovné:

- **Vytvorenie a formalizácia komplexnej sedemblokovej architektúry riadenia** Komplexný rámec štruktúruje proces adaptívneho riadenia do uzavretého kybernetického cyklu.
- **Hybridizácia deterministických a stochastických algoritmov (A + Q-learning)** Významným príspevkom do oblasti operačného výskumu a umelej inteligencie je navrhnutá integrácia grafového algoritmu A-star s metódami posilňovaného učenia.
- **Rozvoj teórie proaktívneho riešenia konfliktov** V rámci teórie multi-agentových systémov práca prináša inovatívny prístup k riešeniu uviaznutí.

7.2 Prínosy pre priemyselnú prax

Z pohľadu aplikovaného výskumu práca prináša okamžite využiteľné metodiky a softvérové architektúry pre podniky transformujúce sa na inteligentné fabriky. Experimentálne overenie potvrdilo nasledujúce konkrétne praktické prínosy:

- **Zvýšenie priepustnosti a priechodnosti systému:** Aplikácia navrhutej metodiky dokázateľne zvyšuje výkonnosť intralogistiky v saturovaných stavoch. Ako ukázali experimenty a štatistické testovanie, prechodom zo statického trasovania na adaptívny prístup bola pri skokovom náraste dopytu dosiahnutá o 21,4% vyššia celková priepustnosť systému (nárast z 42 na 51 ks/hod).
- **Nástroj na podporu manažérskeho rozhodovania:** Práca prostredníctvom multi-kriteriálnej Paretovej analýzy exaktne kvantifikuje kompromisy medzi protichodnými cieľmi. Podnikom poskytuje vizualizovaný rámec, vďaka ktorému môžu dispečeri v reálnom čase na základe aktuálnej situácie voliť medzi stratégiou „expresnej logistiky“ (priorita času) a „zelenej logistiky“ (minimalizácia spotreby energie batérií AGV).
- **Eliminácia logistických kolapsov a nutnosti manuálnych zásahov** Jedným z najkritickejších problémov v praxi sú uviaznutia AGV na uzloch. Nasadením vyvinutého algoritmu na riešenie konfliktov došlo k 100% eliminácii mŕtvych bodov, a zároveň sa štatisticky významne znížila variabilita rozpracovanej výroby.
- **Skokové zvýšenie odolnosti systému a minimalizácia reakčného času** Systém poskytuje podnikom nástroj na okamžité zvládanie krízových situácií. Architektúra dokázala v simulovaných podmienkach detegovať výpadok uzla a kompletne prepočítať celosieťovú topológiu v priemernom čase 1,21 sekundy. Tým sa minimalizujú straty spôsobené prestojmi.

ZÁVER

Prechod k inteligentnému priemyslu so sebou prináša vysokú komplexitu riadenia stochastických a dynamicky sa meniacich procesov. Ako ukázal teoretický výskum a analýza stavu poznania, hoci moderné adaptívne systémy dosahujú vysokú úroveň flexibility, vnútropodniková logistika zaostáva. Tradičné deterministické algoritmy trasovania nedokážu spoľahlivo a bezpečne riadiť rozsiahle flotily AGV v rekonfigurovateľných kompetenčných ostrovoch pri nárazových výkyvoch dopytu alebo neplánovaných poruchách, čo vedie k zahľteniu sietí a mŕtvym bodom.

Predložená dizertačná práca tento problém úspešne rieši návrhom a experimentálnym overením ucelenej metodiky, ktorá sa opiera o sedemblokovú architektúru riadenia. Jadrom tohto systému je hybridizácia heuristického vyhľadávania A-star s metódami posilňovaného učenia (Q-learning). Táto integrácia umožnila prechod logistického riadenia od reaktívneho prístupu k plne prediktívnej kognitívnej autonómii. Systém, založený na digitálnom dvojčati v prostredí Tecnomatix Plant Simulation a pripojený na vrstvu priemyselného IoT, dokáže nielen detegovať aktuálny stav fyzickej linky, ale aj proaktívne predvídať kolízie a dynamicky prepočítavať váhy trás v reálnom čase.

Simulačné overenie, ktoré pozostávalo z 90 nezávislých replikácií a využívalo systematické plánovanie experimentov s vyhodnotením cez analýzu rozptylu (ANOVA), exaktne potvrdilo všetky stanovené vedecké hypotézy. V záťažovom scenári so skokovým nárastom dopytu o 20 % dosiahol adaptívny systém signifikantné zvýšenie celkovej priepustnosti o 21,43 % oproti deterministickému riadeniu. Nasadenie modulu pre včasnú detekciu konfliktov viedlo k absolútnej eliminácii vzniku mŕtvych bodov, čo výrazne stabilizovalo rozptyl rozpracovanej výroby. Navyše, v simulovanom havarijnom scenári systém preukázal extrémnu technologickú odolnosť, keď dokázal identifikovať výpadok kritického uzla a prepočítať obchádzkové trasy pre celú flotilu AGV v priemernom reakčnom čase len 1,21 sekundy.

Dosiahnuté výsledky obohacujú teóriu kyber-fyzikálnych systémov a zároveň predstavujú plne pripravený, bezpečný a prakticky implementovateľný podklad pre transformáciu priemyselných podnikov. Dynamický vývoj smerujúci k Priemyslu 5.0 pritom otvára priestor pre ďalšie smerovanie tohto výskumu. Do blízkej budúcnosti bude kritické rozšíriť simulačné modely o stochastický pohyb ľudských pracovníkov a kolaboratívnych robotov v zdieľaných priestoroch, ako aj aplikovať sofistikovanejšie multi-agentové modely hlbokého posilňovaného učenia pre zvládanie enormne rozsiahlych topológií. Predložená práca tak tvorí pevný teoretický a experimentálny základ pre skutočne inteligentné, adaptívne a udržateľné továrne budúcnosti.

RESUMÉ

The main objective of this dissertation, titled "Routing in Adaptive Logistics Systems," was to propose a routing methodology for the logistics of adaptive systems in a smart industry environment. Its sub-objectives were to design a routing architecture for the logistics of adaptive systems, formulate mathematical models of optimization problems, develop an implementation framework for the methodology, and experimentally validate the proposed solution.

The dissertation thesis addresses the issue of dynamic material flow management and intralogistics in adaptive systems, specifically in environments with a reconfigurable layout organized into flexible competence islands. The primary scientific problem to which this thesis responds is the inability of traditional deterministic routing algorithms and simulation models to effectively manage highly variable demand and stochastic operational disruptions. In saturated systems, this deficiency leads to traffic congestion, deadlocks at intersections, and a subsequent rapid decline in overall production throughput. The aim of this work is to propose a routing methodology for the logistics of adaptive systems. The concept utilizes a predictive digital twin and hybrid artificial intelligence tailored to the demands of Industry 4.0. The result of the research is the formulation of a comprehensive seven-block architectural framework. Through Industrial Internet of Things protocols, this framework interconnects the physical sensory and network layers in real-time with a predictive simulation model developed in the Tecnomatix Plant Simulation environment. The core of the thesis is algorithmic fusion—the integration of deterministic A-star graph search with reinforcement learning methods (Q-learning) for the continuous multi-criteria optimization of logistics routes, thereby minimizing transport time, eliminating collision risks, and accounting for the energy consumption of the autonomous fleet.

This dissertation proposes a novel, proactive routing methodology that anticipates and resolves logistical conflicts before they occur. The core scientific contribution is a hybrid AI framework integrating A-star for rapid geometric pathfinding with Q-learning (reinforcement learning) to dynamically predict and avoid traffic congestion. This model operates within a closed cyber-physical loop, utilizing a Digital Twin (Siemens Tecnomatix) and IoT protocols (OPC-UA, MQTT) for real-time telemetry.

Extensive simulations across demanding stress scenarios validated the methodology, yielding the following key results:

- 21.43% increase in total system throughput under high traffic density.
- Complete elimination of deadlocks during a 20% surge in production demand.
- Rapid recalculation (1.21s) of detour routes during critical node failures.

A Pareto analysis confirmed that while this proactive routing completely eliminates wait times and deadlocks, it marginally increases energy consumption due to the use of longer detour routes. Ultimately, this work provides a robust, highly adaptable solution for modern autonomous intralogistics.

VÝBER ZOZNAMU POUŽITEJ LITERATÚRY

BERNDT, D., SAUER, S., TROSTMANN, E., HAASE, T., HAUPTVOGEL, M. 2022, *Adaptive Produktionsmittel für sich verändernde Bedingungen*. Automatisierungstechnik, vol. 70, no. 6, 2022, pp. 569-579. DOI: 10.1515/auto-2022-0026.

DITTLER, D., LIERHAMMER, P., BRAUN, D., MÜLLER, T., JAZDI, N., WEYRICH M. 2023. *A Novel Model Adaption Approach for intelligent Digital Twins of Modular Production Systems*. 2023 IEEE 28th International Conference on Emerging Technologies and Factory Automation (ETFA), Sinaia, Romania, 2023, pp. 1-8, DOI: 10.1109/ETFA54631.2023.10275384.

ELMARAGHY, H., ELMARAGHY, W. 2022. *Adaptive Cognitive Manufacturing System (ACMS) – a new paradigm*. International Journal of Production Research, 60(24), 7436–7449. DOI: 10.1080/00207543.2022.2078248.

ELMARAGHY, H., MONOSTORI, L., SCHUH, G., ELMARAGHY, W. 2021. *Evolution and future of manufacturing systems*. CIRP Annals, Volume 70, Issue 2, 2021, pp.635-658, DOI: 10.1016/j.cirp.2021.05.008.

GRZNÁR, P., BURGANOVA, N., MOZOL, Š., MOZOLOVÁ, L. 2023, *A Comprehensive Digital Model Approach for Adaptive Manufacturing Systems*. DOI: 10.3390/app131910706.

GRZNÁR, P., GREGOR, M., KRAJČOVIČ, M., MOZOL, Š., SCHICKERLE, M., VAVRÍK, V., ĎURICA, L., MARSCHALL, M., BIELIK, T. 2020 *Modeling and Simulation of Processes in a Factory of the Future*. Appl. Sci. 2020, 10, 4503. DOI: 10.3390/app10134503.

GRZNÁR, P., PAPÁNEK, L., MARČAN, M., KRAJČOVIČ, M., ANTONIUK, I., MOZOL, Š., MOZOLOVÁ, L. 2025 *Enhancing production efficiency through digital twin simulation scheduling*. Appl. Sci. 2025, 15(7), 3637. DOI 10.3390/app15073637.

GUO, Y., ZHOU, J., QIN, Q., WEI, Y., ZHANG, W. 2023. *An Improved Algorithm and Implementation of Data Mining for Intelligent Manufacturing Association Rules Based on Pattern Recognition*. IEEE Consumer Electronics Magazine, vol. 12, no. 2, pp. 94-99, 1 March 2023, DOI: 10.1109/MCE.2022.3149210.

GUO, Z., ZHANG, Y., ZHAO, X., SONG, X. 2021. *CPS-Based Self-Adaptive Collaborative Control for Smart Production-Logistics Systems*. IEEE Transactions on Cybernetics, vol. 51, no. 1, pp. 188-198, Jan. 2021, DOI: 10.1109/TCYB.2020.2964301.

KRAJČOVIČ, M. 2020. *Digitálne projektovanie výrobných a logistických systémov*. Žilina: EDIS. 82s. ISBN 978-80-554-1747-9.

MOZOL, Š., GRZNÁR, P., SCHICKERLE, M. 2020. *Concept of Competence Islands*. INVENTION FOR ENTERPRISE 2020, pp. 116-119. ISBN: 978-83-66249-48-6.

MOZOLOVÁ, L., MOZOL, Š., GRZNÁR, P. 2021. *Dynamic production planning in the concept of competency islands*. Průmyslové inženýrství 2021: Mezinárodní studentská vědecká konference: 10.-11. Brno, pp. 162-167. DOI: 10.24132/PI.2021.07927.162-167.

PIMENTEL, R., SANTOS, P.P.P., CARREIRÃO DANIELLI, A.M., FRAZZON, E.M., PIRES, M.C. 2018. *Towards an Adaptive Simulation-Based Optimization Framework for the Production Scheduling of Digital Industries*. Dynamics in Logistics. LDIC 2018. Lecture Notes in Logistics. Springer, Cham. DOI: 10.1007/978-3-319-74225-0_35.

QUADRAS, D., FRAZZON, E.M., MENDES, L.G., PIRES, M.C., RODRIGUEZ, C.M.T. Adaptive Simulation-Based Optimization for Production Scheduling: A Comparative Study. IFAC-PapersOnLine, Volume 55, Issue 10, 2022, Pages 424-429, DOI: 10.1016/j.ifacol.2022.09.430.

SHEN, T., LI, B. 2024. *Digital twins in additive manufacturing: a state-of-the-art review*. Int J Adv Manuf Technol 131, 63–92 (2024). DOI: 10.1007/s00170-024-13092-y.

SIAFARA, L. C., KHOLERDI, H., BRATUKHIN, A., TAHERINEJAD, N., JANTSCH, A. 2018. *SAMBA – an architecture for adaptive cognitive control of distributed Cyber-Physical Production Systems based on its self-awareness*. Elektrotech. Inftech. 135, 270–277 (2018). DOI: 10.1007/s00502-018-0614-7.

TEERASOPONPONG, S., SOPADANG, A. 2021. *A simulation-optimization approach for adaptive manufacturing capacity planning in small and medium-sized enterprises*. Expert Systems with Applications, Volume 168, 15 April 2021, 114451, DOI: 10.1016/j.eswa.2020.114451.

VAN, M. H., DA SILVA, A. S., KNISSEL, T., WEISS, G. 2023, *Self-Adaptive Service Deployment for Resilience of Smart Manufacturing Architectures*. 4th IEEE International Conference on Automatic Computing and Self-Organizing Systems Companion, ACSOS-C 2023. DOI: 10.1109/ACSOS-C58168.2023.00055.

WIEDEMANN, M., AHMED, O., DIECKHÖFER, A., GASOTO, R., KERNER, S. *Simulation Modeling of Highly Dynamic Omnidirectional Mobile Robots Based on Real-World Data*. 2024 IEEE International Conference on Robotics and Automation (ICRA), Yokohama, Japan, 2024, pp. 16923-16929, DOI: 10.1109/ICRA57147.2024.10611459.

XIAO, G. 2024. *Electronic IoT Technology and Cloud Computing in Intelligent Manufacturing Industry*. 2024 5th International Conference on Mechatronics Technology and Intelligent Manufacturing (ICMTIM), Nanjing, China, 2024, pp. 664-669, DOI: 10.1109/ICMTIM62047.2024.10629544.

ZHOU, J., HE, H., HU, W., WANG, Y. 2024. *Research on modeling and adaptation algorithms for reconfigurable production line systems in discrete workshops*. Proc. SPIE 13226, Third International Conference on Advanced Manufacturing Technology and Manufacturing Systems (ICAMTMS 2024), 132264U. DOI: 10.1117/12.3038260.

Kompletný zoznam použitej literatúry je k dispozícii v dizertačnej práci.

ZOZNAM PUBLIKAČNEJ ČINNOSTI

GRZNÁR, P., PAPÁNEK, L., MARČAN, M., KRAJČOVIČ, M., ANTONIUK, I., MOZOL, Š., MOZOLOVÁ, L. 2025 *Enhancing production efficiency through digital twin simulation scheduling*. Appl. Sci. 2025, 15(7), 3637. DOI 10.3390/app15073637.

KOMAČKA, D., KRAJČOVIČ, M., MATYS, M., MARČAN, M. 2026 *Optimization of in-plant logistics processes in assembly systems using digital simulation tools*. Transportation Research Procedia, Vol. 93, 2026, p. 328-333. DOI: 10.1016/j.trpro.2025.11.050.

MARČAN, M., FURMANN, R., KOMAČKA, D. 2025 *Dynamic routing and real-time decision-making of AGVs*. InvEnt 2025, 44-47 s. ISBN 978-83-947909-9-8.

MARČAN, M., GREGOR, M., PAPÁNEK, L. 2024 *Business process improvement with dynamic simulation support*. InvEnt 2024, 102-105 s. ISBN 978-83-947909-6-7.

MARČAN, M., GRZNÁR, P., PAPÁNEK, L., KOMAČKA, D. *Design and simulation of the AGV logistics system*. Transportation Research Procedia, Vol. 93, 2026, p. 455-458. DOI: 10.1016/j.trpro.2025.11.050.

MARČAN, M., PAPÁNEK, L. 2023 *Wykorzystanie symulacji komputerowej w projektowaniu automatyzacji procesów logistycznych*. Technologie, procesy i systemy produkcyjne, Bielsko-Biala, 99-107 s. ISBN 978-83-67652-11-7.